

基于多代理模型的航空发动机建模及优化方法^{*}

叶一帆, 王占学, 张晓博

(西北工业大学 动力与能源学院 陕西省航空发动机内流动力学重点实验室, 陕西 西安 710129)

摘 要: 为了进一步提高组合模型的模型精度, 提升基于代理模型的优化方法的性能, 本文发展出了一种新的平均组合代理模型, 并将其与 EGO 优化方法相结合, 通过六个解析算例对本文发展的建模方法和优化方法进行了测试。结果表明: 本文发展的建模方法相较于现有方法精度更高, 所发展的优化方法相较于经典代理模型优化方法算法收敛性更强。同时变循环发动机稳态性能建模及加速燃油控制规律优化实例表明, 本文发展的方法在处理实际工程问题时依旧可以表现出良好的算法性能。

关键词: 燃气涡轮发动机; 建模方法; 优化方法; 多代理模型技术; 稳态性能建模; 燃油控制规律优化

中图分类号: V221.8 文献标识码: A 文章编号: 1001-4055 (2021) 12-2684-10
DOI: 10.13675/j.cnki. tjjs. 200817

Multi-Surrogates Based Modelling and Optimization Algorithm Suitable for Aero-Engine

YE Yi-fan, WANG Zhan-xue, ZHANG Xiao-bo

(Shaanxi Key Laboratory of Internal Aerodynamics in Aero-Engine, School of Power and Energy,
Northwestern Polytechnical University, Xi'an 710129, China)

Abstract: In order to improve the performance of aero-engine modelling and optimization algorithm, a new average ensemble model is proposed and used to assist the ego optimization method. By using six well-known mathematical functions with varying dimensions and numbers of training points, it is proved that the proposed ensemble model is more accurate than the other ensemble models, and the convergence of the proposed optimization algorithm is better than that of the classic optimization algorithm. Meanwhile, the steady performance modelling problem of the variable cycle engine and the optimization problem of the variable cycle engine acceleration fuel control schedule are also considered, it is proved that the proposed algorithms perform well in solving a complex engineering problem.

Key words: Gas turbine engine; Modelling approach; Optimization method; Multiple-surrogate model technique; Steady performance modelling; Optimization of fuel control schedule

1 引 言

EGO^[1]是一种经典的代理模型优化方法,直至今日, EGO 方法及其各类改进算法已经广泛应用于航空航天领域各类设计优化问题中^[2-5]。代理模型优化方法
高效全局优化方法 (Efficient global optimization,

^{*} 收稿日期: 2020-10-06; 修订日期: 2021-01-29。

基金项目: 国家自然科学基金 (52076180; 51876176; 51906204); 国家科技重大专项 (2017-I-0001-0001)。

作者简介: 叶一帆, 博士生, 研究领域为基于代理模型的航空发动机性能优化方法。

通讯作者: 张晓博, 博士, 副教授, 研究领域为航空发动机总体性能仿真及多学科设计优化。

引用格式: 叶一帆, 王占学, 张晓博. 基于多代理模型的航空发动机建模及优化方法[J]. 推进技术, 2021, 42(12):2684-2693. (YE Yi-fan, WANG Zhan-xue, ZHANG Xiao-bo. Multi-Surrogates Based Modelling and Optimization Algorithm Suitable for Aero-Engine[J]. *Journal of Propulsion Technology*, 2021, 42(12):2684-2693.)

的基本思路是:首先基于研究对象生成初始样本点并计算其响应值,然后建立研究对象的代理模型,再通过加点准则获取新的样本点,更新代理模型并继续增添新的样本点直到满足优化结束条件。经典EGO方法采用Kriging代理模型,并通过最大化改进期望(Expected improvement, EI^[6])加点准则获得新的样本点。除了EI准则以外,还有改进概率(PI^[7])、模型目标值(MSP^[8])、模型误差(MSE^[9])等准则。其中EI准则由于具备较强的全局收敛性而被广泛应用,这是因为EI准则在预测更优样本点时,同时考虑了代理模型预测值和代理模型预测偏差,而这一预测偏差则由Kriging代理模型提供。

在代理模型理论研究领域,近年来发展出了一种多代理模型技术。多代理模型技术通过同时建立多个不同的代理模型,并将这些代理模型采用加权平均的方式进行组合,以形成预测精度更高、预测稳定性更强的组合代理模型。Goel等^[10]利用均方根交叉验证误差(Generalized Mean Square Cross-Validation Error, GMSE)确定组分模型的误差估计值,然后采用加权平均的方式确定各组分模型的权重。Acar等^[11]提出可以采用优化的方式确定平均组合模型的权重。Viana等^[12]提出了一种基于最小均方根误差(Mean Square Error, MSE)的平均组合模型。Acar^[13]提出了几种基于交叉验证误差的逐点组合模型并进行了对比。Zhou等^[14]通过迭代的方式构建平均组合模型。Lee等^[15]提出采用数个样本点的交叉验证误差确定逐点组合模型的权重。Ferreira等^[16]基于最小二乘法发展了一种组合模型。Liu等^[17]提出了一种新的代理模型局部误差估计方式,并以此构建逐点组合模型。Chen等^[18]将设计空间划分为两类区域,并分别采用平均和逐点组合模型进行建模。Yin等^[19]将设计空间划分为数个子空间,并分别建立组合模型。Ye等^[20]提出了一种新的代理模型局部误差估计方式,并以此开发出了基于最小局部均方根误差(Local Mean Square Error, LMSE)的逐点组合模型。

组合代理模型不仅可以显著提高代理模型的预测精度,还可以改善代理模型优化结果。Samad等^[21]分别使用多项式响应面模型、Kriging模型、径向基神经网络以及一个平均组合模型开展压气机叶片型面优化,研究发现虽然组合模型在任何算例中都不是最优的方法,但其总能提供最为稳定的设计优化结果。Glaz等^[22]也采用包含一个平均组合模型的多个代理模型开展转子减振研究,他们发现采用组合模型可以优化得到采用单一模型可能漏掉的最优结

果。因此,一些研究者将组合代理模型与经典EGO方法相结合,以进一步提升代理模型优化方法的性能。但是EGO方法对模型预测偏差的需求也限制了这类研究的发展。Ginsbourger等^[23]提出可以建立多个不同核函数的Kriging模型的组合模型,再采用EGO方法进行优化。Palar等^[24]基于这一思路,建立了不同建模参数的Kriging模型,对比分析了基于不同组合Kriging模型的EGO方法的算法性能。Ferreira等^[25]提出的基于最小二乘方法的组合模型^[16]可以提供组合模型预测偏差,因此他们基于这一预测偏差将该组合模型引入到EGO方法中。目前多代理模型技术发展的主要问题有:(1)截至目前在代理模型建模方法研究的公开文献中,平均组合模型和逐点组合模型的精度不存在绝对的优劣关系,最新相关研究往往集中于组合模型权重的确定方式,而忽略了代理模型误差估计方式的改进;(2)组合模型无法完全应用于经典EGO优化方法中,因为组合模型往往需要集成不同种类的代理模型,如径向基函数模型^[26]和Kriging模型^[27],但是径向基函数模型无法像Kriging模型一样提供EGO优化方法所需要的模型预测偏差。

本文首先提出一种新的代理模型全局误差估计方式,相较于经典的GMSE,可以更加准确地预估代理模型全局误差,基于此建立的平均组合代理模型的精度也更高。然后定义一种新的组合模型预测偏差估计方式,从而将任意组合模型引入到EGO方法中,以此进一步提升代理模型优化方法的性能。

2 基于多代理模型的建模及优化方法

2.1 多代理模型技术简介

现阶段,多代理模型技术主要应用于代理模型建模与代理模型优化两个领域。其中,在代理模型建模领域,多代理模型技术的应用较为成熟;而在代理模型优化领域,多代理模型技术的应用则处于起步阶段。

2.1.1 多代理模型建模技术

多代理模型建模技术通过同时建立多种不同类型或不同建模参数的组分代理模型,采用加权平均的方式将建立的多个组分代理模型进行组合,形成组合代理模型,即

$$y_e'(\mathbf{x}) = \sum_{i=1}^m w_i(\mathbf{x}) y_i'(\mathbf{x}) \quad (1)$$

$$\sum_{i=1}^m w_i(\mathbf{x}) = 1 \quad (2)$$

式中 $\mathbf{x}$ 为输入向量; $w_i(\mathbf{x})$ 为第 i 个组分代理模型在 $\mathbf{x}$ 处的权重; $y_i'(\mathbf{x})$ 为第 i 个组分代理模型在 $\mathbf{x}$ 处的预测值; $y_e'(\mathbf{x})$ 为组合模型在 $\mathbf{x}$ 处的预测值; m 为组分代理模型的个数。

如果权重在整个样本空间中保持不变,则称组合模型为全局组合代理模型,如果权重在整个样本空间中会变化,则称为逐点组合代理模型。为了获得组合代理模型的权重,近年来最为流行的方法是基于每个代理模型的交叉验证误差(Cross-Validation Error)来确定权重。交叉验证误差的定义为

$$e_{CV}(\mathbf{x}_k) = y(\mathbf{x}_k) - y_{-k}'(\mathbf{x}_k) \quad (3)$$

式中 $\mathbf{x}_k$ 代表第 k 个样本点; $e_{CV}(\mathbf{x}_k)$ 为第 k 个样本点处的交叉验证误差; $y(\mathbf{x}_k)$ 为第 k 个样本点处的真实响应值; $y_{-k}'(\mathbf{x}_k)$ 为通过除了第 k 个样本点以外的所有样本点所建立的代理模型在第 k 个样本点处的预测值。

交叉验证误差本身可以用作估计代理模型在样本点附近的局部误差,而代理模型在所有样本点处的交叉验证误差的均方根值,即通用均方根交叉验证误差(Generalized Mean Square Cross-Validation Error, GMSE),则可以用于估计代理模型的全局误差,代理模型的通用均方根交叉验证误差 e_{GMSE} 为

$$e_{GMSE} = \sqrt{\sum_{k=1}^n (e_{CV}(\mathbf{x}_k))^2 / n} \quad (4)$$

式中 $\mathbf{x}_k$ 代表第 k 个样本点; $e_{CV}(\mathbf{x}_k)$ 为代理模型在第 k 个样本点处的交叉验证误差; n 为样本点个数。

2.1.2 多代理模型优化技术

多代理模型优化技术即是在优化过程中采用基于多代理模型技术所建立的组合模型,而非单一模型。在经典 EGO 优化方法中,加点准则通过 Kriging 模型的预测值和预测偏差确定新的样本点。以 EI 加点准则为例,假设模型的真实响应值 $y(\mathbf{x})$ 服从以 Kriging 模型预测值 $y'(\mathbf{x})$ 为期望、Kriging 模型预测偏差 $s(\mathbf{x})$ 为标准差的正态分布

$$y(\mathbf{x}) \in N[y'(\mathbf{x}), s^2(\mathbf{x})] \quad (5)$$

式中 N 代表正态分布函数。

那么在某个点 $\mathbf{x}$ 处目标函数的改进 $I(\mathbf{x})$ 可以定义为

$$I(\mathbf{x}) = \max[y_{\text{best}} - y(\mathbf{x}), 0] \quad (6)$$

式中 y_{best} 代表当前最优样本点的响应值。

而点 $\mathbf{x}$ 处的目标改进期望则定义为

$$E[I(\mathbf{x})] = s(\mathbf{x})[u\Phi(u) + \phi(u)] \quad (7)$$

$$u(\mathbf{x}) = \frac{y_{\text{best}} - y(\mathbf{x})}{s(\mathbf{x})}$$

式中 $\Phi(u)$ 和 $\phi(u)$ 分别代表正态分布累积分布函数和正态分布概率密度函数。

在 EI 准则中,通过最大化改进期望来确定新样本点的位置。计算新样本点的响应并更新 Kriging 模型后,继续通过 EI 准则获取下一样本点直至满足优化结束条件。

经典 EGO 方法对代理模型预测偏差的需求限制了组合模型在 EGO 方法中的应用。现阶段多代理模型优化技术的主要思路包含:(1)仅使用可以提供代理模型预测偏差的代理模型构建组合模型,例如 Ginsbourger 等^[23]和 Palar 等^[24]建立 Kriging 模型的组合模型开展 EGO 优化。(2)针对组合模型建立预测偏差,例如 Ferreira 等^[16,25]基于最小二乘方法建立组合模型,该组合模型可以提供预测偏差,从而可以直接应用到 EGO 方法中。

2.2 基于多代理模型技术的建模及优化方法研究

本文首先基于多代理模型技术提出了一种基于交叉验证误差均值-方差的代理模型全局误差估计方式(Mean-Variance Error, MVE),并将其应用于组合模型建模中。然后提出了一种组合模型预测偏差估计方法(Ensemble Prediction Variance, EPV),并以此建立了基于组合模型的序列组合优化方法(Sequential Ensemble Optimization, SEO)。

2.2.1 基于误差均值-方差的组合模型(MVE)

现有全局组合代理模型往往采用 GMSE 作为组分代理模型的误差估计方式,并将 GMSE 较小的组分模型赋予更高的权重。GMSE 提供了组分代理模型交叉验证误差的全局均值信息,不能反映交叉验证误差的偏离程度。具有相同或相近 GMSE 的组分代理模型可能其中一个组分代理模型在各个样本点处的交叉验证误差相近,但是另一个组分代理模型在某些样本点处交叉验证误差很小,但是在其他样本点处交叉验证误差很大。因此在建立组合代理模型时,应该给前者赋予更高的权重,这就需要在组分代理模型误差估计时,考虑组分代理模型在样本点处的交叉验证误差之间的偏差信息。

在本文提出的 MVE 中,代理模型交叉验证误差的均值和偏差作为评判代理模型全局精度的依据。代理模型交叉验证误差的偏差为

$$e_{VAR} = \sum_{k=1}^n |e_{CV}(\mathbf{x}_k) - e_{GMSE}| / n \quad (8)$$

式中 $\mathbf{x}_k$ 代表第 k 个样本点; $e_{CV}(\mathbf{x}_k)$ 为代理模型在第 k 个样本点处的交叉验证误差; n 为样本点个数。

而 MVE 则通过下式计算获得, 即

$$e_{MVE} = e_{GMSE} e_{VAR} \quad (9)$$

基于 MVE, 本文提出两种平均组合模型 (PE1, PE2)。在 PE1 中, 各组分代理模型的权重通过其误差估计之间的相对大小来确定。而在 PE2 中, 将具有最小误差估计的组分代理模型权重赋 1, 其他组分代理模型权重赋 0。两种平均组合模型的权重分别可通过式 (10) 和式 (11) 计算得到。

$$w_i = e_{MVE,i}^{-2} / \sum_{i=1}^m e_{MVE,i}^{-2} \quad (10)$$

$$w_i = \begin{cases} 1 & e_{MVE,i} = \min_{i=1,\dots,m} (e_{MVE,i}) \\ 0 & \text{else} \end{cases} \quad (11)$$

式中 w_i 为第 i 个组分代理模型的权重; m 为组分代理模型的个数。

其中 PE1 的权重确定方式和 Viana 等^[12]提出的方法一样, 区别在于本文采用 MVE 作为代理模型全局误差估计, 而 Viana 等^[12]采用 GMSE 作为代理模型全局误差估计。本文将在数值测试中对测试两种组合模型的精度, 以验证本文所提出的 MVE 能否比 GMSE 更加精确地估计代理模型全局误差。而 PE2 则可以看作是一类代理模型选择方法, 本文将在数值测试中对比 PE1 和 PE2 的模型精度及用于优化时优化算法的性能, 以确定本文与所提出的代理模型全局误差估计方式相匹配的权重确定方式。

2.2.2 序列组合优化方法 (SEO)

组分模型的预测偏差 (Model Prediction Variance, MPV) 定义为

$$\nu_{MPV} = \sqrt{\frac{\sum_{i=1}^m (y'_i(\mathbf{x}) - y'_e(\mathbf{x}))^2}{m}} d \quad (12)$$

$$d = \|\mathbf{x} - \mathbf{x}_{NO}\| / l$$

式中 d 代表距离修正项; $\mathbf{x}_{NO}$ 代表距离点 $\mathbf{x}$ 最近的样本点; l 为当前所有样本点之间距离的均值。

在本文提出的 SEO 方法中, MPV 和 Kriging 模型提供的预测偏差 KPV (Kriging Prediction Variance) 共同组合为 EPV (Ensemble Prediction Variance), 即

$$\nu_{EPV} = \sum_{i=1}^{m_{Krg}} \nu_{KPV,i} + \sum_{i=1}^{m_{else}} \nu_{MPV,i} \quad (13)$$

式中 m_{Krg} 代表组分模型中 Kriging 模型的个数; m_{else} 代表组分模型中其他模型的个数。

基于组合模型的预测值和 EPV 来确定新的样本点。SEO 方法的算法流程图如图 1 所示。




Fig. 1 Flow chart of SEO algorithm

首先建立初始样本集并计算其响应值, 然后以此建立构建组合模型所需要的组分模型, 例如径向基模型和 Kriging 模型。通过 Kriging 模型可以获得模型预测值和基于 KPV 的模型预测偏差, 通过径向基模型可以获得模型预测值和基于 MPV 的模型预测偏差。然后通过 Kriging 模型预测值和径向基模型预测值可以获得组合模型预测值, 通过 KPV 和 MPV 可以获得组合模型预测偏差 EPV。基于组合模型预测值和预测偏差, 结合 EI 加点准则获得新的样本点。将新的样本点加入样本集合中并更新代理模型进一步获得下一样本点直至优化结束。

根据采用组合模型的不同, 序列组合优化方法可分为 SEO-PE1 和 SEO-PE2, 本文将在测试算例中对比这两种优化方法。

3 航空发动机建模及优化研究

3.1 建模及优化方法测试算例

本文采用了 6 个数值算例和 2 个航空发动机总体性能工程应用算例对提出的建模方法和优化方法进行测试。

3.1.1 数值算例

6 个数值算例均从代理模型建模及优化研究领

域公开文献中选取,以对比本文所发展的代理模型建模方法相较于其他公开文献中已发表的代理模型建模方法的精度。本文选择了不同维度的测试函数以校核本文所发展的建模方法和优化方法在面向不同维度的问题时的适用性。6个测试函数分别如下所示。

(1) Branin-Hoo(BH)函数

$$y = \left(x_2 + \frac{5.1x_1^2}{4\pi^2} + \frac{5x_1}{\pi} - 6 \right)^2 + 10 \left(1 - \frac{1}{8\pi} \right) \cos x_1 + 10 \quad (14)$$

式中 $x_1 \in [-5, 10]$, $x_2 \in [0, 15]$ 。

(2) Camelback(Ca)函数

$$y = \left(4 - 2.1x_1^2 + \frac{x_1^4}{3} \right) x_1^2 + x_1 x_2 + \left(-4 + 4x_2^2 \right) x_2^2 \quad (15)$$

式中 $x_1 \in [-3, 3]$, $x_2 \in [-2, 2]$ 。

(3) Multi-model(M)函数

$$y = x_1 x_2 \sin(x_1) + \frac{x_1^2}{10} + x_1 - 1.5x_2 \quad (16)$$

式中 $x_1, x_2 \in [-2, 2]$ 。

(4) Colville(Co)函数

$$y = 100(x_1^2 - x_2)^2 + (x_1 - 1)^2 + (x_3 - 1)^2 + 90(x_3^2 - x_4)^2 + 19.8(x_2 - 1)(x_4 - 1) + 10.1((x_2 - 1)^2 + (x_4 - 1)^2) \quad (17)$$

式中 $x_1, x_2 \in [-2, 2]$ 。

(5) ExtendedRosen(ER)函数

$$y = - \sum_{i=1}^{m-1} (1 - x_i)^2 - \sum_{i=1}^{m-1} 100(x_{i+1} - x_i^2)^2 \quad (18)$$

式中 $x_i \in [-5, 10]$ 。

(6) DixonPric(DP)函数

$$y = (x_1 - 1)^2 + \sum_{i=2}^m i [2x_i^2 - x_{i-1}]^2 \quad (19)$$

式中 $x_i \in [-10, 10]$ 。

测试建模方法时,本文对每个数值算例选取三种不同的样本集大小测试建模方法的精度,以校核本文所发展的建模方法在面向不同样本集大小时的适用性,并且每个数值算例都会多次求解以降低样本设计对建模方法精度的影响。其中样本集通过拉丁超立方方法生成(Latin Hypercube Sampling, LHS),表1中给出了建模方法测试算例。表中BH,Ca以及M测试函数的维度为2;Co,ER和DP测试函数的维度分别为4,8,12。本文针对每个测试函数均选取了三种不同的样本集大小进行测试,三种样本集大小分

别为测试函数维度的6,12,18倍,即对BH(2.),Ca(2.)以及M(2.)三个测试函数选取了大小为12,24以及36的三个样本集,对Co(4.)选取了大小为24,48以及72的三个样本集,对ER(8.)选取了大小为48,96以及144的三个样本集,对DP(12.)选取了大小为72,144,216的三个样本集。而测试集的大小则统一选取为1000。针对BH(2.),Ca(2.),M(2.)以及Co(4.)这四个测试函数,本文会重复建模30次以降低样本设计对建模方法精度的影响,而针对ER(8.)和DP(12.)这两个测试函数,为了节省计算资源,本文会重复建模10次以降低样本设计对建模方法精度的影响。

Table 1 Summary of modelling functions

Function	Size of training set	Size of test set	Number of training and test sets
BH(2.)	12, 24, 36	1000	30
Ca(2.)	12, 24, 36	1000	30
M(2.)	12, 24, 36	1000	30
Co(4.)	24, 48, 72	1000	30
ER(8.)	48, 96, 144	1000	10
DP(12.)	72, 144, 216	1000	10

Goel^[10]和OWS^[12]属于平均组合模型,而Acar^[13]则属于逐点组合模型,这三类模型均广泛用于近年来的组合模型对比研究中。而且本文所提出的PE1方法与OWS方法所采用的代理模型权重确定方式相同,这两类方法的性能差异就是代理模型误差估计方式的差异导致的。另外,这三类组合模型均使用代理模型交叉验证误差或其均值作为代理模型的误差估计方式,而本文所提出的MVE则是基于代理模型交叉验证误差的基础上发展而来的新的误差估计方式,选用这三类模型作为对比模型可以确定本文所提出的MVE是否可以提高组合代理模型的精度。

本文选取了三个RBF模型和两个Kriging模型作为组分模型。其中三个RBF模型分别采用高斯、多二次、薄板样条核函数,三个RBF模型的形状参数均取1。两个Kriging模型都选择高斯相关性函数,而趋势函数则分别选择常数趋势函数和线性趋势函数。

测试优化方法时,优化目标均为函数值最小,初始样本集采用LHS方法生成,优化加点分别采用经典EGO方法和本文提出的SEO优化方法生成,其中在SEO方法中分别使用PE1和PE2组合模型(SEO-PE1方法,SEO-PE2方法),以分析两种组合模型在面向优化问题时的优劣。优化加点准则都使用EI准

则。每个数值算例都会多次求解以降低样本设计及智能优化算法对优化结果的影响。表 2 中给出了优化方法测试算例。

Table 2 Summary of optimization functions

Functions	Size of initial data set	Optimization cycles	Number of initial data sets
BH(2.)	12	36	100
Ca(2.)	12	36	100
M(2.)	12	36	100
Co(4.)	24	48	30
ER(8.)	48	96	10
DP(12.)	72	144	10

3.1.2 基于数据的变循环发动机稳态性能建模

为了进一步验证本文所提出的建模方法在面向实际工程问题时的性能,本文所发展的多代理模型建模方法还将应用于基于数据的变循环发动机(Variable Cycle Engine, VCE)稳态性能建模问题,以验证本文所发展方法在面向航空发动机总体性能实际工程问题时的适用性。

航空发动机总体性能仿真模型可分为基于模型的方法和基于数据的方法。基于数据的航空发动机总体性能仿真模型可为航空发动机控制和健康管理提供推力估计。推力估计本身即可看作是基于数据建立航空发动机推力值的代理模型,通过代理模型与航空发动机推力进行预测,常用的方法包括极限学习机^[28-29]、径向基函数^[30]、支持向量机^[31]等。

因此,本文选取基于数据的变循环航空发动机稳态性能代理模型,建立作为验证本文所提出的建模方法的实际工程算例。相较于常规涡喷、涡扇发动机而言,变循环航空发动机的部件数和可调参数均更多,这提升了代理模型建模的难度。本文利用变循环航空发动机总体性能仿真程序^[32]生成用于建立代理模型的样本集和用于测试代理模型精度的测试集。变循环发动机仿真模型如图 2 所示。

本文选择变循环航空发动机在亚声速巡航状态(飞行高度为 11km,飞行马赫数为 0.9)下的推力和耗

油率 sfc 作为代理模型建模的对象。而变循环发动机亚声速巡航状态稳态模型的输入参数及变化范围如表 3 所示,样本集采用 LHS 方法生成,样本集大小为 300,而测试集采用随机方法生成,测试集大小为 1000。

Table 3 Range of design variables for VCE

Design variables	Low limit	Up limit
Fan design bypass ratio	0.1	0.7
Fan design pressure ratio	3	4.5
Core driven fan stage design bypass ratio	0.2	0.5
Core driven fan stage design pressure ratio	1.2	1.8
Compressor design pressure ratio	5	9
Combustor chamber outlet temperature/K	1650	1950
Fan relative spool speed/%	70	100
Core fan stage inlet guide vane angle/(°)	0	45
Low pressure turbine nozzle relative area/%	70	130
Front variable area inject inner duct relative area/%	-50	50
Rear variable area inject inner duct relative area/%	-50	50

3.1.3 基于代理模型的变循环发动机加速过程燃油控制规律优化

为了进一步验证本文所提出的优化方法在面向实际工程问题时的性能,本文所发展的多代理模型建模方法还将应用于变循环发动机加速过程燃油控制规律优化问题,以验证本文所发展方法在面向航空发动机总体性能实际工程问题时的适用性。

航空发动机过渡态控制规律设计对航空发动机动态性能至关重要,良好的航空发动机过渡态控制规律,可以尽可能发挥出航空发动机的性能潜力,在保证加减速过程中发动机稳定工作的前提下尽可能缩短过渡态所需要的时间。目前关于航空发动机过渡态控制规律设计方法的研究大多为基于航空发动机动态仿真模型的带约束优化研究。通过在发动机动态过程的一系列离散时间点中,建立以发动机某个参数最大化或最小化为优化目标的子优化问题,采用优化算法对发动机动态过程燃油流量进行优化,最终获得整个过渡态过程的燃油控制规律。而




Fig. 2 Variable cycle engine

最新研究^[33]表明这类方法所获得的控制规律并非全局最优,并提出直接优化航空发动机过渡态控制规律曲线的全局优化方法,但是这类方法也相应地提高了计算代价和优化问题求解难度。

因此,本文针对变循环发动机加速过程,开展燃油控制规律全局优化研究。本文采用的变循环发动机过渡态性能仿真程序同样来自于文献[32],而燃油控制规律全局优化问题求解方法则分别采用经典 EGO 方法和本文提出的 SEO-PE1 方法和 SEO-PE2 方法。

变循环发动机加速过程燃油控制规律优化问题可表示为

$$\begin{aligned} & \min t(\mathbf{x}) \\ & \text{s.t.} \begin{cases} C_L(\mathbf{x}) \geq C_{L,\min} \\ C_U(\mathbf{x}) \leq C_{U,\max} \\ x_i \in [0,1], \quad i = 1,2,\dots,20 \end{cases} \end{aligned} \quad (20)$$

式中 $t(\mathbf{x})$ 表示加速过程所需要的时间; $C_L(\mathbf{x})$ 表示加速过程中的下边界约束,如风扇喘振裕度(10%),核心机驱动风扇级(CDFS)喘振裕度(10%),压气机喘振裕度(10%); $C_U(\mathbf{x})$ 表示加速过程中的上边界约束,如燃烧室出口总温(1700K); $C_{U,\max}$ 和 $C_{L,\min}$ 分别表示上、下边界约束值; $\mathbf{x}$ 表示燃油变化率控制点。

设置动态过程终控制点燃油变化率为0,则可以通过燃油变化率控制点转换得到发动机具体燃油控

制规律,将燃油控制规律输入图2中的仿真模型则可以得到变循环发动机加速过程中各个参数的变化规律。

3.2 结果与讨论

3.2.1 组合模型建模结果及分析

表4为6个数值算例以及变循环发动机稳态性能建模算例,给出了 Goel^[10], Acar^[13], OWS^[12] 三种对比组合模型以及 PE1 和 PE2 组合模型的均方根误差 RMSE。为了便于对比分析,表4中还在括号中给出了经过归一化的均方根误差值,即除以了当前算例中最精确组合模型的均方根误差,并且每个测试算例中最精确的组合模型被加粗表示。根据测试结果可以看出,本文所提出的两种组合模型的精度都明显优于三种对比组合模型。

本文所提出的 PE1 组合模型要比 PE2 组合模型性能表现更好。尽管在所有测试算例中, PE2 组合模型 11 次获得了最精确的建模结果, PE1 组合模型 9 次获得了最精确的建模结果。但是 PE1 组合模型比 PE2 组合模型更为稳定。PE1 在 16 个测试算例中相对误差值 < 1.03, 而 PE2 仅在 13 个测试算例中相对误差值 < 1.03; PE1 仅在 1 个测试算例中相对误差值 > 1.05, 而 PE2 在 4 个测试算例中相对误差值 > 1.05。另外, PE1 仅在 BH(24.) 中比 1 个对比模型(Acar)精度低, 而 PE2 则在 BH(24.) 算例中比 Acar 和 OWS 对比模型精度低, 在 BH(36.) 和 Ca(36.) 测试算例中比 OWS 对比模型精度低, 在发动机推力测试算例中比

Table 4 RMSE of each ensemble model

Item	Goel	Acar	OWS	PE1	PE2
BH(12.)	22.3(1.12)	23.2(1.17)	21.3(1.07)	20.2(1.02)	19.8(1.00)
BH(24.)	14.8(1.11)	13.3(1.00)	13.9(1.05)	13.7(1.03)	14.4(1.08)
BH(36.)	9.93(1.13)	9.40(1.07)	8.85(1.00)	8.81(1.00)	9.47(1.07)
Ca(12.)	17.8(1.16)	17.0(1.11)	17.2(1.12)	15.7(1.02)	15.4(1.00)
Ca(24.)	12.0(1.25)	11.8(1.23)	11.4(1.19)	10.3(1.07)	9.62(1.00)
Ca(36.)	7.25(1.11)	7.54(1.15)	6.83(1.04)	6.54(1.00)	7.06(1.08)
M(12.)	0.269(1.17)	0.260(1.12)	0.257(1.11)	0.232(1.01)	0.231(1.00)
M(24.)	0.0735(1.20)	0.0745(1.21)	0.0643(1.03)	0.0614(1.00)	0.0620(1.01)
M(36.)	0.0345(1.63)	0.0358(1.69)	0.0251(1.18)	0.0214(1.01)	0.0213(1.00)
Co(24.)	2.23(1.05)	1.99(1.05)	2.31(1.03)	2.64(1.00)	2.76(1.00)
Co(48.)	1.91(1.06)	1.82(1.05)	2.61(1.04)	2.30(1.01)	2.36(1.00)
ER(110.)	3.12×10 ⁵ (1.47)	2.51×10 ⁵ (1.19)	2.62×10 ⁵ (1.23)	2.12×10⁵(1.00)	2.15×10 ⁵ (1.01)
ER(220.)	2.80×10 ⁵ (1.49)	2.28×10 ⁵ (1.21)	2.30×10 ⁵ (1.22)	1.88×10⁵(1.00)	1.89×10⁵(1.00)
DP(182.)	1.99×10 ⁵ (1.58)	1.46×10 ⁵ (1.16)	1.66×10 ⁵ (1.32)	1.26×10⁵(1.00)	1.26×10⁵(1.00)
DP(364.)	1.84×10 ⁵ (1.74)	1.25×10 ⁵ (1.18)	1.42×10 ⁵ (1.34)	1.06×10⁵(1.00)	1.06×10⁵(1.00)
Thrust	642.4(1.04)	623.1(1.01)	634.7(1.03)	618.8(1.00)	658.8(1.06)
sfc	0.1947(1.21)	0.1799(1.12)	0.1845(1.15)	0.1630(1.02)	0.1605(1.00)

全部对比模型精度低。

另外,本文所提出的 PE1 组合模型与对比模型 OWS 的差异仅是所采用的模型全局误差估计方式不同,OWS 模型中采用 GMSE 作为模型全局误差估计方式,而 PE1 模型中采用本文提出的 MVE 作为模型全局误差估计方式。从结果中可看出,除了在 BH(36.) 算例中本文所提出的 PE1 模型精度与 OWS 模型相同,在其他所有测试问题中本文所提出的 PE1 模型精度均明显高于 OWS 模型。这表明本文所提出的模型全局误差估计方式 MVE 明显优于 GMSE,可以更加准确地预估代理模型的全局误差,从而有效提高组合代理模型的精度。

综上所述,本文所提出的 MVE 代理模型全局误差估计可以更好地估计代理模型的误差,从而进一步提升组合模型的精度,而基于 MVE 采用加权平均的方式所建立的组合模型(PE1)精度更好。


3.2.2 组合模型优化结果及分析

表 5 中给出了 6 个数值算例以及变循环发动机加速燃油控制规律优化算例,采用经典 EGO 方法和本文提出的 SEO-PE1,SEO-PE2 方法所获得的优化结果。其中在每个测试问题中获得最优结果的优化方法已被加粗。


Table 5 Comparison of optimization result			
Optimization result	EGO	SEO-PE1	SEO-PE2
BH	0.402	0.402	0.400
Ca	-1.029	-1.031	-1.030
M	-3.120	-3.120	-3.120
Co	558	539	454
ER	2384	1213	1505
DP	9030	1025	1214
Acceleration time/s	7.1	6.5	6.9

根据测试结果可以看出,无论是数值测试算例还是变循环发动机加速过程燃油控制规律优化算例,本文所提出的 SEO 方法所获得的优化结果均优于经典 EGO 方法。且 SEO-PE1 和 SEO-PE2 优化方法表现的性能相近。对于 BH,Ca,M 四个二维优化算例,EGO 方法获得的结果已经接近理论最优解,本文所提出的 SEO 方法所获得的结果与 EGO 方法相近。而对于 ER,DP 两个高维优化问题,SEO 方法所获得的结果明显优于 EGO 方法。对于变循环发动机加速燃油控制规律优化问题,通过 SEO 方法优化获得的燃油控制规律,可以明显缩减发动机加速过程所需要的时间。

图 3 给出了经典 EGO 方法和本文提出的两种优化方法所计算得到的变循环发动机加速过程优化结果。其中图 3(a)是燃烧室出口温度随时间的变化规律,图 3(b)是压气机喘振裕度随时间的变化规律,风扇和 CDFS 喘振裕度在动态过程中未明显靠近约束边界,在此没有给出。其中黑色实线是通过 EGO 方法获得的结果,红色实线是通过 SEO-PE1 方法获得的结果,蓝色实线是通过 SEO-PE2 方法获得的结果。



(a) Combustor outlet temperature



(b) Compressor surge margin

Fig. 3 Optimization results of engine acceleration process

从图中可以看出,通过 SEO 方法所获得的燃油控制规律变化更快,且压气机喘振裕度和燃烧室出口温度也更靠近所规定的约束边界。由图 3(b)中可以看出,在采用 EGO 方法优化获得的燃油控制规律下,压气机喘振裕度先降低而后维持在距离约束边界稍远的位置最后逐渐升高,而在采用 SEO 方法优化获得的燃油控制规律下,压气机喘振裕度则可以更加靠近约束边界。这是因为相较于 EGO 方法中采用的 Kriging 模型,SEO 方法中采用的 PE1 和 PE2 组合模型可以更加精确地预测动态过程中压气机最低喘振裕度,从而 SEO 方法更容易获得靠近压气机喘振边界的燃油控制规律,而在这种燃油控制规律下,发动机加速时间也更短。另外,通过 SEO-PE1 所获得

的燃油控制规律优于通过 SEO-PE2 所获得的燃油控制规律。根据 3.2 节中所获得的结果可知, PE1 比 PE2 能够提供更稳定的预测精度。在基于代理模型的优化问题中, 每增添一个样本点就需要重新建立代理模型并预估下一个样本点。因此预测精度更为稳定的代理模型则可以在这一过程中持续获得更好的样本点, 从而可以获得更优的优化结果。

4 结 论

本文对基于多代理模型的航空发动机建模及优化方法进行了研究, 可以得到以下结论:

(1) 相较于常用的代理模型全局误差估计方式 GMSE, 本文提出的 MVE 可以更好地估计代理模型全局误差的相对大小, 以此建立的组合模型精度也更高。

(2) 解析算例测试证明, 相较于现有的组合代理模型, 本文所提出的基于 MVE 的组合代理模型 PE1 和 PE2 在大部分问题中获得了最精确的结果, 而 PE1 的性能表现则更为稳定。相较于经典的 EGO 方法, 本文所提出的序列组合优化方法 SEO-PE1 和 SEO-PE2 总能获得更好的优化结果。

(3) 变循环发动机稳态性能建模算例表明, 本文所提出的 PE1 方法获得了比现有组合代理模型更好的建模结果。而变循环发动机加速燃油控制规律优化算例表明, 本文所提出的序列组合优化方法 SEO-PE1 能够获得更优的加速燃油控制规律。

致 谢: 感谢国家自然科学基金、国家科技重大专项的资助。

参考文献

- [1] Jones D R, Schonlau M, Welch W J. Efficient Global Optimization of Expensive Black-Box Functions [J]. *Journal of Global Optimization*, 1998, 13(4): 455-492.
- [2] 薛 亮, 韩万金. 基于遗传算法与近似模型的全局气动优化方法[J]. *推进技术*, 2008, 29(3): 360-366. (XUE Liang, HAN Wan-jin. Global Aerodynamic Optimization Method Using Genetic Algorithms and Surrogate Mode [J]. *Journal of Propulsion Technology*, 2008, 29(3): 360-366.)
- [3] 赵 勇, 李本威, 朱飞翔, 等. 基于 QPSO 算法的压气机特性代理模型优化[J]. *推进技术*, 2014, 35(11): 1537-1543. (ZHAO Yong, LI Ben-wei, ZHU Fei-xiang, et al. Surrogate Model Optimization of Compressor Characteristics Based on QPSO Algorithm [J]. *Journal of Propulsion Technology*, 2014, 35(11): 1537-1543.)
- [4] 韩昌富, 刘 波, 张博涛. 损失及落后角代理模型在多级轴流压气机特性预测中的应用[J]. *推进技术*, 2020, 41(7): 1493-1501. (HAN Chang-fu, LIU Bo, ZHANG Bo-tao. Application of Loss and Deviation Surrogate Model in Prediction of Multistage Axial Compressor Characteristics [J]. *Journal of Propulsion Technology*, 2020, 41(7): 1493-1501.)
- [5] 韩忠华, 许晨舟, 乔建领, 等. 基于代理模型的高效全局气动优化设计方法研究进展[J]. *航空学报*, 2020, 41(5): 30-70.
- [6] Mockus J. On Bayesian Methods for Seeking the Extremum [C]. *Berlin: Optimization Techniques IFIP Technical Conference*, 1975.
- [7] Forrester A I J, Keane A J. Recent Advances in Surrogate-Based Optimization [J]. *Progress in Aerospace Sciences*, 2009, 45(1): 50-79.
- [8] Booker A J, Dennis J J, Frank P D, et al. A Rigorous Framework for Optimization of Expensive Functions by Surrogates [J]. *Structural Optimization*, 1998, 17(1): 1-13.
- [9] Sasena M J, Papalambros P Y, Goovaerts P. Exploration of Metamodeling Sampling Criteria for Constrained Global Optimization [J]. *Engineering Optimization*, 2002, 34: 263-278.
- [10] Goel T, Haftka R T, Shyy W, et al. Ensemble of Surrogates [J]. *Structural and Multidisciplinary Optimization*, 2007, 33: 199-216.
- [11] Acar E, Rais-Rohani M. Ensemble of Metamodels with Optimized Weight Factors [J]. *Structural and Multidisciplinary Optimization*, 2009, 37: 279-294.
- [12] Viana F A C, Haftka R T, Steffen V. Multiple Surrogates: How Cross-Validation Errors Help Us to Obtain the Best Predictor [J]. *Structural and Multidisciplinary Optimization*, 2009, 39: 439-457.
- [13] Acar E. Various Approaches for Constructing an Ensemble Metamodels Using Local Measure [J]. *Structural and Multidisciplinary Optimization*, 2010, 42: 879-896.
- [14] Zhou X J, Ma Y Z, Li X F. Ensemble of Surrogates with Recursive Arithmetic Average [J]. *Structural and Multidisciplinary Optimization*, 2011, 44: 651-671.
- [15] Lee Y, Choi D H. Pointwise Ensemble of Metamodels Using V Nearest Points Cross-Validation [J]. *Structural and Multidisciplinary Optimization*, 2014, 50: 383-394.
- [16] Ferreira W G, Serpa A L. Ensemble of Metamodels: The Augmented Least Squares Approach [J]. *Structural and Multidisciplinary Optimization*, 2016, 53: 1019-1046.
- [17] Liu H, Xu S, Wang X. Optimal Weighted Pointwise Ensemble of Radial Basis Functions with Different Basis Functions [J]. *AIAA Journal*, 2016, 54: 3117-3133.

- [18] Chen L, Qiu H, Jiang C, et al. Ensemble of Surrogates with Hybrid Method Using Global and Local Measures for Engineering Design[J]. *Structural and Multidisciplinary Optimization*, 2018, 57: 1711–1729.
- [19] Yin H, Fang H, Wen G, et al. On the Ensemble of Metamodels with Multiple Regional Optimized Weight Factors[J]. *Structural and Multidisciplinary Optimization*, 2018, 58: 245–263.
- [20] Ye Y, Wang Z, Zhang X. An Optimal Pointwise Weighted Ensemble of Surrogates Based on Minimization of Local Mean Square Error[J]. *Structural and Multidisciplinary Optimization*, 2020, 62: 529–542.
- [21] Samad A, Kim K Y, Goel T, et al. Multiple Surrogate Modeling for Axial Compressor Blade Shape Optimization[J]. *Journal of Propulsion and Power*, 2008, 24(2): 302–310.
- [22] Glaz B, Goel T, Liu L, et al. Multiple-Surrogate Approach to Helicopter Rotor Blade Vibration Reduction[J]. *AIAA Journal*, 2009, 47(1): 271–282.
- [23] Ginsbourger D, Helbert C, Carraro L. Discrete Mixtures of Kernels for Kriging-Based Optimization[J]. *Quality and Reliability Engineering International*, 2008, 24(6): 681–691.
- [24] Palar P S, Shimoyama K. Efficient Global Optimization with Ensemble and Selection of Kernel Functions for Engineering Design[J]. *Structural and Multidisciplinary Optimization*, 2019, 59: 93–116.
- [25] Ferreira W G, Serpa A L. Ensemble of Metamodels: Extensions of the Least Squares Approach to Efficient Global Optimization[J]. *Structural and Multidisciplinary Optimization*, 2018, 57: 131–159.
- [26] Hardy R L. Multiquadric Equations of Topography and Other Irregular Surfaces[J]. *Journal of Geophysical Research Atmospheres*. 1971, 76: 1905–1915.
- [27] Sacks J, Welch W J, Mitchell T J, et al. Design and Analysis of Computer Experiments[J]. *Statistical Science*, 1989, 4(4): 409–435.
- [28] 宋汉强, 李本威, 张 赞, 等. 基于聚类与粒子群极限学习机的航空发动机推力估计器设计[J]. 推进技术, 2017, 38(6): 1379–1385. (SONG Han-qiang, LI Ben-wei, ZHANG Yun, et al. Aero-Engine Thrust Estimator Design Based on Clustering and Particle Swarm Optimization Extreme Learning Machine[J]. *Journal of Propulsion Technology*, 2017, 38(6): 1379–1385.)
- [29] 赵姝帆, 李本威, 宋汉强, 等. 基于K-均值聚类与粒子群核极限学习机的推力估计器设计[J]. 推进技术, 2019, 40(2): 259–266. (ZHAO Shu-fan, LI Ben-wei, SONG Han-qiang, et al. Thrust Estimator Design Based on K-Means Clustering and Particle Swarm Optimization Kernel Extreme Learning Machine[J]. *Journal of Propulsion Technology*, 2019, 40(2): 259–266.)
- [30] Li Z Q, Zhao Y P, Cai Z Y, et al. A Proposed Self-Organizing Radial Basis Function Network for Aero-Engine Thrust Estimation[J]. *Aerospace Science and Technology*, 2019, 87: 167–177.
- [31] Ren L H, Ye Z F, Zhao Y P. A Modeling Method for Aero-Engine by Combining Stochastic Gradient Descent with Support Vector Regression[J]. *Aerospace Science and Technology*, 2020, 99(10).
- [32] Zhang X, Wang Z, Zhou L, et al. Multidisciplinary Design Optimization on Conceptual Design of Aero-Engine[J]. *International Journal of Turbo and Jet Engines*, 2016, 33(2): 195–208.
- [33] Zheng Q, Zhang H. A Global Optimization Control for Turbo-Fan Engine Acceleration Schedule Design[J]. *Proceedings of the IMechE, Part G: Journal of Aerospace Engineering*, 2018, 232(2): 308–316.

(编辑:朱立影)